Iranian Food Science and Technology Research Journal
Vol. 16, No. 1, Apr. May. 2020, p. 145- 156

نشریه پژوهشهای علوم و صنایع غذایی ایران
جلد 16، شماره 1 ،فروردین -اردیبهشت 1399 ص.156-145

کوتاه پژوهشی

پیش بینی برخی ویژگی‌های کیفی میوه انبه رقم کلک سرخ با استفاده از پردازش تصاویر رنگی و شبکه‌های عصبی مصنوعی

امید دوستی ایرانی[1]- عباس روحانی[1]- محمودرضا گلزاریان[1*]- منصوره شمیلی[2]- پیمان آذرکیش[3]

تاریخ دریافت: 1397/09/26
تاریخ پذیرش: 1398/04/01

چکیده

درجه‌بندی میوه از نظر ویژگی‌های کیفی از جمله سفتی، مواد جامد محلول و اسیدیته، به‌صورت غیرمخرب در امر بازارپسندی آن تأثیر به‌سزایی دارد. در این پژوهش با استفاده از ترکیب تکنیک‌های پردازش تصویر و هوش مصنوعی، پیش‌بینی ویژگی‌های کیفی انبه رقم کلک سرخ مورد بررسی قرار گرفته است. نمونه‌های مورد بررسی در دو تیمار دمایی 5، 15 و تیمار شاهد (24 درجه سانتی‌گراد) به مدت 48 ساعت قرار گرفتند. پس از آن به مدت 14 روز به‌صورت یک روز در میان تصویربرداری از نمونه‌ها انجام و ویژگی‌های رنگی از نواحی مورد نظر در محیط رنگی L*a*b استخراج شدند. پس از هر مرحله تصویربرداری میزان اسیدیته، قند و سفتی بافت اندازه‌گیری شد. به‌منظور بررسی ارتباط بین خصوصیات فیزیکوشیمیایی و مشخصه‌های تصویری بین نمونه‌ها، شبکه عصبی چندلایه پرسپترون ایجاد و آموزش داده شد. از این شبکه تربیت شده به‌منظور پیش بینی ویژگی‌های فیزیکی از روی مشخصه‌های رنگی استفاده شد. متغیرهای ورودی به شبکه شامل تیمار دمایی در سه سطح (شاهد، 15 و 5 درجه سانتی‌گراد)، کانال‌های رنگی (L, a, b) و میزان انحراف معیار کانال‌های رنگی (stdL, stda, stdb) است. متغیرهای خروجی نیز شامل قند، اسیدیته و سفتی بافت است. نتایج حاصل از پیش‌بینی مدل شبکه عصبی نشان داد که دقت مدل در مرحله آزمون برای پیش‌بینی فاکتورهای اسیدیته، قند و سفتی بافت به‌ترتیب برابر با 45، 85، 88 درصد است؛ بنابراین هرچند دقت مدل شبکه عصبی برای پیش‌بینی اسیدیته از روی فاکتورهای رنگی نمونه‌های انبه پایین بود، اما شبکه عصبی مبتنی بر ماشین بینایی قادر به پیش‌بینی فاکتورهای سفتی و قند با دقت بالا است.

واژه‌های کلیدی: انبه، ماشین بینایی، شبکه عصبی، ویژگی‌های کیفی.

مقدمه

اخیرا تقاضای مصرف‌کنندگان برای میوه و سبزی‌ها با کیفیت بالا در حال افزایش است. با توجه به این موضوع، افزایش دقت و قابلیت اعتماد در بخش عملیات پس از برداشت از جمله ارزیابی کیفی باید برای همه میوه‌ها انجام شود. بدیهی است که این امر باید به‌صورت سریع و غیرمخرب صورت گیرد (خدابخشیان کارگر، 1394). آزمایش‌های غیرمخرب به روش‌هایی گفته می‌شود که در آن‌ها محصول مورد نظر هیچ‌گونه آسیبی ندیده، قابلیت برگشت دوباره به چرخه مصرف را داشته باشد و نیز اثر زیانبار روش‌های فتوفیزیکی، گرمایی، شیمیایی، مکانیکی و فتوشیمیایی را نداشته باشند (نیکبخت و همکاران، 1389). روش‌های پرشماری برای ارزیابی کیفی محصولات کشاورزی به‌صورت غیرمخرب ابداع شده‌اند که تنها برخی از آن‌ها توانسته‌اند شرایط مطلوب را برآورده کرده و از لحاظ فنی و صنعتی قابلیت توجیه داشته باشند. روش‌های چشمی (اپتیکی)، امواج الکترومغناطیسی و صوتی در توسعه آزمون‌های غیرمخرب نقش اساسی داشته‌اند، اما در عین حال این روش‌ها می‌توانند ویژگی‌های محدودی را در محصولات باغبانی به‌ویژه در میوه‌ها بررسی کنند؛ بنابراین لازم است شرایط حاکم بر این روش‌ها به دقت بررسی و در گزارش یا ثبت نتایج آزمایش لحاظ شوند (خدابخشیان کارگر و همکاران، 1394). در میان روش‌های نام برده، استفاده از روش پردازش تصویر در حال گسترش بوده و ارزش قابل توجهی برای صنعت غذا دارد (میرحسینی و همکاران، 1397). ماشین بینایی که مبتنی بر پردازش تصویر است شاخه‌ای از هوش مصنوعی است، که در آن بینایی انسان شبیه‌سازی می‌شود. از این سامانه‌ها می‌توان

1- گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد.
2- گروه علوم باغبانی و مهندسی فضای سبز، دانشکده کشاورزی، دانشگاه هرمزگان
3 - گروه علوم باغبانی و مهندسی فضای سبز، دانشکده کشاورزی، دانشگاه فردوسی مشهد
(* - نویسنده مسئول: Email: m.golzarian@um.ac.ir)
DOI: 10.22067/ifstrj.v16i2.77537

برای کنترل کیفیت، جداسازی و درجه‌بندی محصولات کشاورزی استفاده کرد (پوردربانی و همکاران، 1388).مبحث کنترل کیفیت میوه به دلیل اینکه بسیاری از خواص فیزیکی و مکانیکی میوه باید مورد بررسی قرار گیرد بسیار پیچیده است (Nordey *et al*.2014). صفات کیفی میوه بستگی به غلظت متابولیت‌های اولیه از جمله قند، اسیدهای آلی و آمینواسیدها و همچنین متابولیت‌های ثانویه از جمله رنگدانه‌ها، ویتامین‌ها و عطر دارد (Genard *et al*. 2008; Lechaudel *et al*. 2007). بسیاری از میوه‌ها در طی رسیدن پس از برداشت، تحت تغییرات شدید رنگ قرار می‌گیرند از جمله این میوه‌ها می‌توان به انبه، موز و سیب اشاره نمود. در میوه انبه رنگ گوشت جزء مهمی از کیفیت میوه است و نقش مهمی در بازارپسندی و رضایت مشتری دارد (Medlicott *et al*. 1986). انبه (*Mangifera indica L.*) یکی از میوه‌های گرمسیری است که از اهمیت اقتصادی بالایی برخوردار است. با توجه به ماهیت فرازگرای میوه انبه، در مناطق تولید تجاری، میوه‌ها در مرحله سبز رسیده و یا در مرحله ابتدایی تغییر رنگ از سبز به سایر رنگ‌ها (بسته به رقم) برداشت می‌شوند. در صورت کاربرد تیمارهای مناسب پس از برداشت، کیفیت میوه حداقل 2 تا 4 هفته حفظ خواهد شد (آذرکیش و شمیلی، 1394). بعضی از پارامترهای رسیدگی میوه انبه عبارت‌اند از درصد مواد جامد محلول، اسیدیته، کربوهیدرات‌ها، وزن مخصوص و ترکیبات فنلی (محمدپور و سماوی، 1393). درصد بالای مواد جامد محلول در تعیین کیفیت میوه برای مصرف تازه‌خوری و یا تهیه محصولات فرآوری شده از میوه انبه اهمیت دارد و یکی از شاخص‌های مهم در تعیین بلوغ میوه انبه است (عباسی و همکاران، 1391). سفتی بافت میوه انبه (در زمان شروع آزمایش 11، 10 و 8/2 کیلوگرم بر سانتی‌متر مربع) با افزایش مدت نگهداری (تا روز پانزدهم به 3/4، 3 و 2/5 کیلوگرم بر سانتی‌متر مربع) به تدریج کاهش می‌یابد (کلانتری و همکاران، 1392). هرچه از مدت زمان نگهداری میوه انبه بگذرد در نتیجه باعث افزایش سرعت تنفس و تسریع سنتز آنزیم‌های تخریب کننده دیواره سلول مانند پلی‌گالاکتوروناز شده و در نهایت منجر به نرم شدن میوه انبه می‌گردد (Jacobi et al.2001). محققین دریافتند که میزان مواد جامد محلول میوه انبه سبز رسیده رقم داشه هاری[1] از زمان شروع آزمایش تا روز ششم نگهداری در دمای اتاق از 10 به 16 درصد افزایش یافت و سپس تا روز پانزدهم به تدریج کاهش یافت (Rathore *et al*.2007). این درحالی است که مواد جامد محلول در برخی ارقام انبه در هند بین 12- 8 درصد گزارش شده است (More *et al*. 2004). pH میوه با گذشت زمان نگهداری تا حدودی افزایش می‌یابد که می‌تواند بیانگر مصرف اسیدهای آلی در طول زمان باشد (کلانتری و همکاران، 1392). ارزیابی بصری بسیار خسته‌کننده و زمان‌بر است. ابزاری که اندازه‌گیری مناسبی از رنگ سطح میوه ارائه می‌کنند، مقایسه مناسبی از کیفیت میوه را در طول مکان، زمان و فصل تولید آن را فراهم می‌آورند. در پژوهشی، برای اندازه‌گیری تغییرات رنگ استفاده از کرومومتر Minolta یا رنگ‌سنج[2] Hunter Lab پیشنهاد شده است (Le´on *et al*. 2006). روش دیگری جهت دریافت اطلاعات رنگ، استفاده از سیستم بینایی کامپیوتر (CVS[3]) می‌باشد. CVS شامل روشنایی استاندارد، یک دوربین برای تهیه تصویر و نرم‌افزاری جهت پردازش تصویر است (Pedreschi *et al*,2006). دوستی‌ایرانی و همکاران (1394) بررسی تغییرات رنگ و دمای بافت لیهده و سالم سیب رقم گلدن دلیشز با استفاده از پردازش تصاویر مرئی و گرمایی را مورد ارزیابی قرار داده‌اند. همچنین در پژوهشی دیگر تخمین عمق لهیدگی با استفاده از پردازش تصاویر گرمایی و مدل رگرسیون مورد بررسی قرار گرفته است (دوستی‌ایرانی و همکاران، 2016). گلزاریان و همکاران (1395) تشخیص آسیب‌های مکانیکی میوه انبه را با استخراج ویژگی‌های رنگی در دو مدل رنگی RGB و L*a*b* مورد بررسی قرار دادند.در این پژوهش درصد مساحت استخراج شده از هر نمونه معیاری برای درجه‌بندی میوه انبه مورد استفاده قرار گرفت. با استفاده از روش خوشه‌بندی k میانگین و مقایسه میانگین خوشه‌ها با استاندارد آمریکایی (USDA,2006)، درجه‌بندی با قدرت تفکیک بالا حاصل شد. در بررسی سلمانی‌زاده و همکاران (1392) به بررسی امکان‌سنجی استفاده از جذب اشعه ایکس به‌عنوان یک روش غیرمخرب برای تعیین برخی از شاخص‌های کیفی میوه انار پرداخته شده است. با توجه به تحقیقات انجام شده این طور نتیجه می‌شود که کیفیت میوه تشکیل شده از ویژگی‌هایی چون بافت، میزان قند، اسیدیته، عطر، عمر مفید میوه که از جمله ویژگی‌های مهم و ذاتی میوه می‌باشند. علاوه بر این موارد ممکن است فاکتورهای ارزیابی کیفیت ظاهری میوه در ارتباط با ویژگی‌های کیفی داخلی میوه باشند و از جمله مهمترین آن‌ها می‌توان به رنگ و ابعاد میوه اشاره نمود. در این پژوهش فرض می‌شود که بین رنگ میوه انبه و ویژگی‌های کیفی داخلی شامل قند، سفتی و اسیدیته ارتباطی وجود دارد. بنابراین هدف از این پژوهش بررسی وجود یا عدم وجود ارتباط بین ویژگی‌های استخراج شده از رنگ میوه (فاکتورهای رنگی RGB وL*a*b) انبه رقم کلک سرخ با ویژگی‌های کیفی محصول (قند، سفتی و اسیدیته) است. بررسی این ارتباط و قابلیت پیش‌بینی فاکتورهای کیفی محصول با استفاده از شبکه عصبی چندلایه پرسپترون است.

1 Variety Dashehari

2 Colorimeter

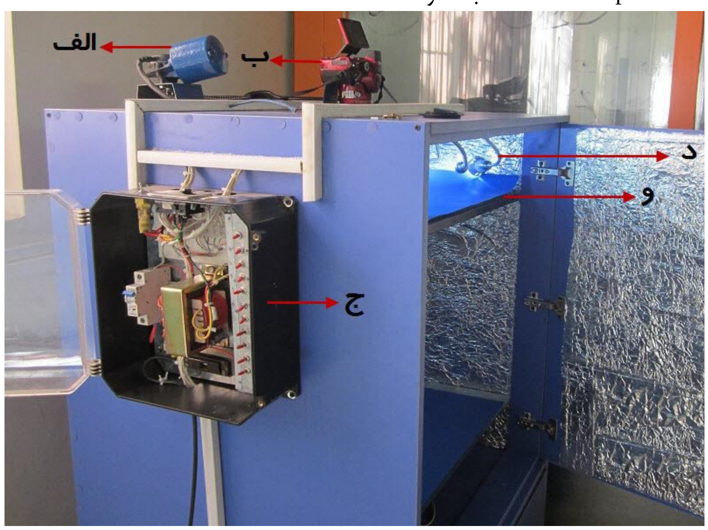
3 Computer Vision System

مواد و روش‌ها

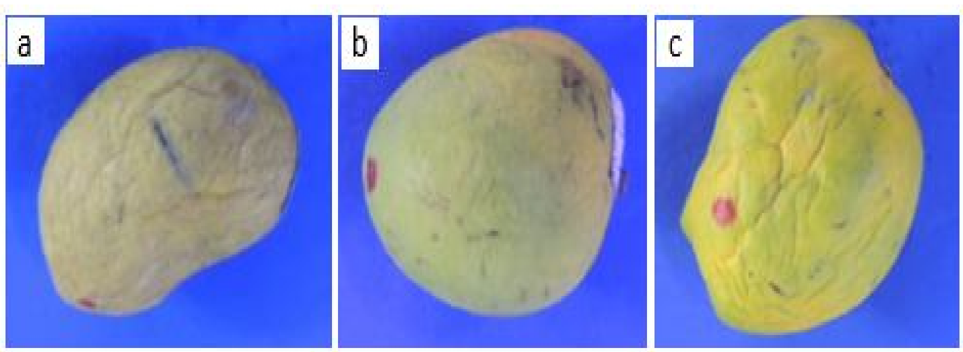
نمونه‌های مورد آزمایش انبه رقم کلک سرخ از باغات میناب واقع در استان هرمزگان تهیه و به آزمایشگاه پردازش تصویر (دمای 24 درجه سانتی‌گراد و رطوبت نسبی 22%) منتقل شدند. نمونه‌ها در 3 تیمار دمایی 5، 15 و تیمار شاهد (24 درجه سانتی‌گراد) به مدت 48 ساعت قرار گرفتند. سپس همه نمونه‌ها در دمای محیط قرار گرفته و پس از آن به مدت 14 روز به‌صورت یک روز در میان تصویربرداری از نمونه‌ها انجام و پس از هر مرحله تصویربرداری آزمون‌های ارزیابی کیفی به‌صورت مخرب انجام شد. در این ارزیابی میزان قند، سفتی و اسیدیته میوه مورد ارزیابی قرار گرفته است.

تصویربرداری

جهت تصویربرداری از اتاقک تصویربرداری شکل 1 استفاده شد (گلزاریان و همکاران، 1392). تصاویر در طیف مرئی توسط یک دوربین Nikon Coolpix P510 Nikon Inc, Japan با قدرت تفکیک 16/1 مگاپیکسل تهیه شد. به‌منظور قرارگیری کامل نمونه‌ها در حوزه دید دوربین، با توجه به فاصله کانونی لنز در دوربین فاصله بین دوربین و نمونه‌ها 20 سانتی‌متر در نظر گرفته شد. تصویربرداری به نحوی است که نمونه‌ها در زیر دوربین قرار گرفته و از یک نمای مشخص شده از نمونه تصویر گرفته می‌شود. نورپردازی مناسب به هنگام تصویربرداری سبب سهولت در آنالیز تصاویر می‌گردد. همان‌طور که در شکل 1 مشاهده می‌شود نورپردازی به نحوی است که از تشکیل سایه و نقاط متمرکز نوری در تصویر جلوگیری شود. همچنین از یک پس‌زمینه به رنگ آبی برای تصویربرداری استفاده شد. در شکل 2 سه تصویر از نمونه‌های مورد آزمایش در دمای 5 درجه سانتی‌گراد، 15 درجه سانتی‌گراد و دمای اتاق (تیمار شاهد) در مرحله آخر نگهداری میوه‌ها نمایش داده شده است. در شکل 2 تیمار 5 درجه‌سانتی‌گراد با حرف (a)، تیمار 15 درجه سانتی‌گراد با حرف (b) و تیمار شاهد با حرف (c) نمایش داده شده است.



شکل 1- اتاقک عکس‌برداری. الف) موتور، جهت تغییر ارتفاع صفحه‌ی پس‌زمینه. ب) دوربین که بر روی پایه‌ی اتاقک نصب‌شده است. ج) تابلوی کنترل روشنایی و لامپ‌های LED و راه‌اندازی موتور بالابرنده. د) لامپ LED به همراه پایه؛ و) صفحه پس‌زمینه



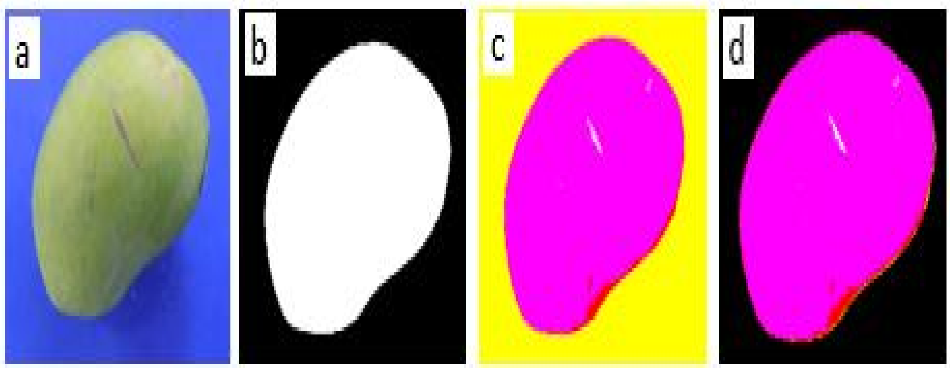
شکل 2- تصویربرداری انجام شده از نمونه‌ها در سه تیمار، به‌ترتیب از چپ به راست، 5، 15 درجه سانتی‌گراد و تیمار شاهد

اندازه‌گیری ویژگی‌های کیفی شامل قند، سفتی و اسیدیته

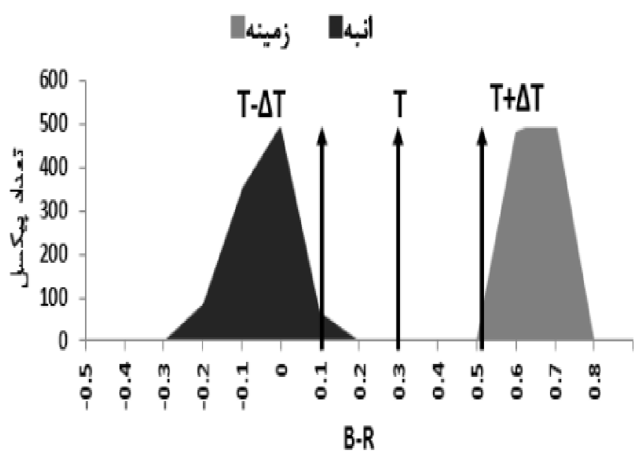
برای اندازه‌گیری قند میوه از دستگاه رفراکتومتر استفاده شد (Arzani and Koushesh, 2005). به‌منظور اندازه‌گیری سفتی بافت میوه از دستگاه سفتی‌سنج (OSK-10576) با پروب استوانه‌ای به قطر 8 میلی‌متر استفاده شد. میزان فشار دستگاه بر حسب کیلوگرم بر سانتی‌متر مربع محاسبه شد (Hertog *et al*. 2004). برای اندازه‌گیری pH از دستگاه pHسنج (Metrohm، 744، سوئیس) استفاده شد؛ که نتایج به‌صورت درصد اسید مالیک بیان گردید (Roussos et al. 2011). برای انجام این سه آزمایش نمونه‌ها تخریب و از چرخه آزمایش خارج می‌شدند.

ویژگی‌های رنگی

پس از تصویربرداری از نمونه‌ها تصاویر موردنظر در نرم‌افزار Matlab نسخه R2011a (Mathworks Inc, US) مورد پردازش قرار گرفتند. همان‌طور که در شکل 3 مشاهده می‌شود به‌منظور نمونه‌برداری از میوه انبه پس از فراخوانی تصاویر در نرم‌افزار، ویژگی‌های رنگی از نواحی مورد نظر در محیط رنگی L*a*b استخراج شدند. در شکل سه از چپ به راست، تصویر a نشان دهنده تصویر RGB اولیه، تصویر b، نشان‌دهنده تصویر باینری، تصویر c تصویر تبدیل شده از محیط RGB به محیط L*a*b* ، تصویر d نشان‌دهنده تصویر L*a*b است که در آن پس زمینه به‌واسطه ضرب تصویر c در تصویر b حاصل شده است. به‌منظور باینری کردن تصویر اولیه از حد آستانه به‌دست آمده از تفاضل دو کانال آبی و قرمز (b-r) استفاده شده است (گلزاریان و همکاران، 1395) در شکل 4 این حد آستانه نمایش داده شده است. در الگوریتم پردازش تصویر مطابق با شکل 4، مقدار حد آستانه در ویژگیb-r برابر با 0/3 درنظر گرفته شده است.



شکل 3- مراحل استخراج ویژگی‌های رنگی در محیط L*a*b؛ a) تصویر اصلی. b) تصویر باینری تصویر اصلی، c) تصویر تبدیل یافته در محیط L*a*b، d) حذف پس‌زمینه در تصویر c.



شکل 4- هیستوگرام تعیین حد آستانه مناسب به‌منظور جداسازی انبه از پس‌زمینه.

تبدیل مدل رنگی RGB به L*a*b

در این تحقیق از دو محیط رنگی RGB (مدل رنگ پایه) و L*a*b استفاده شد. بر اساس مدل رنگی RGB هر رنگ از ترکیب مقادیری از سه رنگ اصلی قرمز، سبز و آبی تشکیل شده است. برای تبدیل این مدل به مدل رنگی L*a*b یکی از روش‌ها تبدیل مستقیم مقادیر RGB به L*a*b می‌باشد (León *et al*. 2006). در این روش، ابتدا فضای رنگی RGB به فضای رنگی پایه XYZ تبدیل و با استفاده از رابطه1 مقدار L* که بیانگر میزان درخشندگی در تصویر می‌باشد به دست می‌آید. دررابطه2 مقدار a* قابل محاسبه می‌باشد که این مقدار بیانگر میزان تغییر رنگ از سبز به قرمز و در رابطه 3 مقدار b به دست می‌آید که بیانگر میزان رنگ از آبی به زرد است.

$$\widehat{L^*} = \begin{cases} 116\left(\frac{Y}{Y_n}\right)^{1/3} - 16\ if\ \frac{Y}{Y_n} > 0.008856 \\ 903.3\,\frac{Y}{Y_n} \qquad \le 0.08856 \end{cases} \quad (1)$$

$$\widehat{a}^* = 500\left[(\frac{X}{X_n})^{1/3} - (\frac{Y}{Y_n})^{1/3}\right] \quad (2)$$

$$\widehat{b}^* = 200\left[(\frac{Y}{Y_n})^{1/3} - (\frac{Z}{Z_n})^{1/3}\right] \quad (3)$$

ساختار شبکه عصبی مورد استفاده

در این تحقیق از شبکه چندلایه پرسپترون با یک لایه مخفی استفاده شده است. تعداد نرون‌ها در لایه مخفی برابر با 25 در بهترین حالت به دست آمد. حداکثر تکرار شبکه برای آموزش برابر با 1000 و نرخ یادگیری برابر با 0/001 درنظر گرفته شده است. از تابع انتقال تانژانت سیگموئید (Tansig) و الگوریتم آموزشی Trainlm در ساختار شبکه استفاده شده است. متغیرهای ورودی شامل 7 متغیر شامل، تیمار دمایی (T) در سه سطح (شاهد، 15 و 5 درجه سانتی‌گراد)، کانال‌های رنگی (L, a, b) و میزان انحراف معیار کانال‌های رنگی (stdl, stda, stdb) است. متغیرهای خروجی نیز شامل قند، اسیدیته و سفتی بافت است. مرحله بعد از آماده‌سازی داده‌ها، نرمالیزه‌کردن آن‌ها است. تا مجموعه داده‌های آموزش و تست دارای توزیع آماری تقریبا یکنواختی شوند. همچنین باید این تبدیل در دامنه تغییرات مناسبی انجام تا شبکه به نقطه بهینه همگرا شود و آز آن‌جا که تابع انتقال انتخاب شده برای نرون‌های لایه مخفی شبکه سیگموئید است، بنابراین بهترین دامنه تبدیل داده‌ها [0/9- 0/1] است (Rohani et al, 2011). برای این منظور از نرمالیزاسیون خطی برای تبدیل داده‌ها استفاده شده است (رابطه 4).

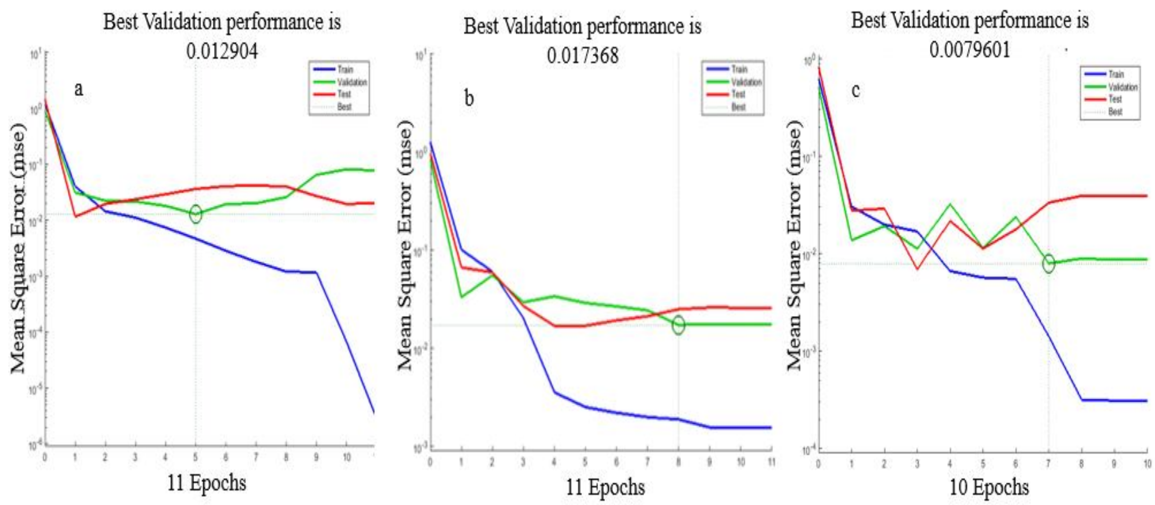
$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \times (r_{max} - r_{min}) + r_{min} \quad (4)$$

در رابطه فوق X داده خام اولیه، x_n داده نرمالیزه شده، max و x_{mi} به‌ترتیب مقادیر بیشینه و کمینه داده‌های اولیه و r_{min} و r_{max} به تتیب حد بالی و پایینی دامنه تغییرات داده‌های تبدیل شده است. 80 درصد از داده‌ها به‌عنوان داده‌های آموزش، 10 درصد از داده‌های برای فاز اعتبارسنجی مدل و 10 درصد باقی مانده در فاز آزمون مورد استفاده قرار گرفته اند.

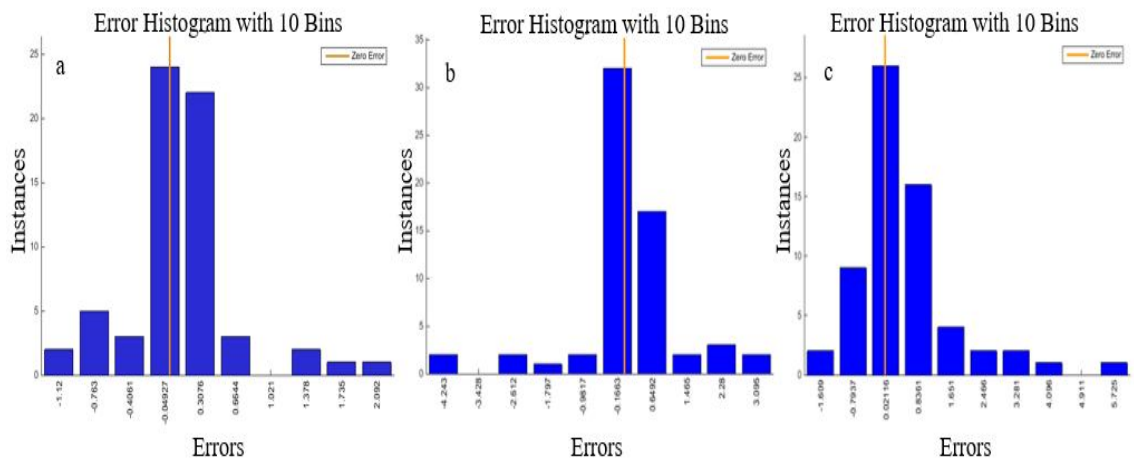
نتایج و بحث

در شکل 5 نمودار عملکرد شبکه عصبی برای سه حالت آموزش، اعتبار و تست برای هر سه حالت اسیدیته، سفتی و قند نمایش داده شده است. این نمودار که شامل سه نمودار به رنگ آبی، سبز و قرمز است به‌ترتیب برای داده‌های آموزش، اعتبارسنجی و آزمایش است. محور افقی نشان‌دهنده تعداد تکرار آموزش شبکه است که در آن تکرار شبکه آموزش دیده است. نمودارهای عملکردی از یک نقطه با خطای مشخص شروع می‌شوند و با تکرار آموزش شبکه مقدار خطا کاهش یافته و پس از نقطه همگرایی ثابت می‌شود. همانطور که مشاهده می‌شود برای فاکتور اسیدیته، سفتی و قند تعداد تکرار شبکه به‌ترتیب برابر با (5، با عملکرد 0/012904)، (8، با عملکرد 0/017368) و (7، با عملکرد 0/0079601) به‌دست آمده است. این نقطه بهینه با دو خط چین و دایره سبز رنگ نمایش داده شده است. بعد از این مرحله خطای مراحل آموزش، اعتبارسنجی و آزمون، مقدار ثابتی به خود گرفته‌اند. محور عمودی نیز میانگین مربعات خطا را در نقطه‌ای که شبکه همگرا شده است، نشان می‌دهد. همانطور که مشاهده می‌شود برای پیش‌بینی اسیدیته میوه انبه با استفاده از ویژگی‌های رنگی میانگین مربعات خطا نسبت به دو فاکتور سفتی و قند بیشتر است.

در شکل 6 هیستوگرام خطا مربوط به سه مدل شبکه عصبی نمایش داده شده است. در این نمودار محور افقی مقدار خطا یا اختلاف خروجی و خروجی مطلوب است. در واقع پس از آموزش شبکه بیشترین و کمترین خطا محاسبه شده و تعداد نمونه‌هایی که دارای خطایی در هر محدوده هستند؛ مشخص می‌شوند. خط نارنجی نشان‌دهنده خطای صفر است که هرچه تعداد نمونه‌ها در محدوده نزدیک‌تر به این خط قرار بگیرند و از توزیع نرمال‌تری برخوردار باشد، نشان‌دهنده این است که شبکه عصبی از مدل رگرسیونی بهتری برخوردار است. حروف a، b و c به‌ترتیب مربوط به پیش‌بینی اسیدیته، سفتی و قند است و همانطور که مشاهده می‌شود وضعیت شبکه در دو حالت پیش‌بینی سفتی و قند انبه بهتر از حالت پیش‌بینی اسیدیته است.



شکل 5- نمودار عملکرد شبکه عصبی برای سه متغیر اسیدیته (a)، سفتی (b) و قند (c)



شکل 6- هیستوگرام خطا برای سه متغیر اسیدیته (a)، سفتی (b) و قند (c)

در جدول 1 سایر فاکتورهای ارزیابی مدل شبکه عصبی به‌ترتیب برای سه متغیر اسیدیته، سفتی و قند بیان شده است. مقدار RMSE کل که بیانگر میانگین مربعات خطا می‌باشد، برای متغیر اسیدیته برابر با 0/58، برای متغیر سفتی 1/26 و برای متغیر قند برابر با 1/34 است. مقدار MAPE که بیانگر متوسط خطای پیش‌بینی شبکه عصبی است، برای اسیدیته، سفتی و قند به‌ترتیب برابر با 9/53، 22/74 و 6/14 است. پارامتر EF بیانگر بازده مطلق شبکه است که بیشترین مقدار آن برای متغیر سفتی حاصل شده است.

در جدول 2 مدل‌های رگرسیونی خطی در سه فاز آموزش، اعتبارسنجی و فاز آزمون ارائه شده است. در فاز آموزش و اعتبار سنجی روابط به دست آمده از ضریب تبین بالایی برخوردار هستند. در فاز آزمون مدل‌های حاصل شده مقدار ضریب تبیین مدل برای پیش‌بینی اسیدیته برابر با 0/45، پیش‌بینی سفتی برابر با 0/85 و برای پیش‌بینی قند برابر با 0/88 است. به‌طور کلی نتایج نشان می‌دهد که روابط به‌دست آمده تنها برای پیش‌بینی فاکتورهای سفتی و قند از دقت کافی برخوردار هستند و پیش‌بینی اسیدیته با استفاده از این روش با دقت غیرکاربردی امکان‌پذیر است.

شاخص‌هایی مانند اندازه، وزن، شکل، میزان مواد جامد محلول، اسیدیته، بافت و عمرقفسه‌ای از ویژگی‌هایی هستند که در گزینش ارقام و ژنوتیپ‌های برتر انبه مورد توجه قرار می‌گیرند؛ زیرا شاخص‌های فیزیکی- بیوشیمیایی علاوه بر این که در تعیین بلوغ و کیفیت داخلی میوه مهم هستند، تعیین کننده نیاز بازار نیز می‌باشند (عباسی و همکاران، 1391).

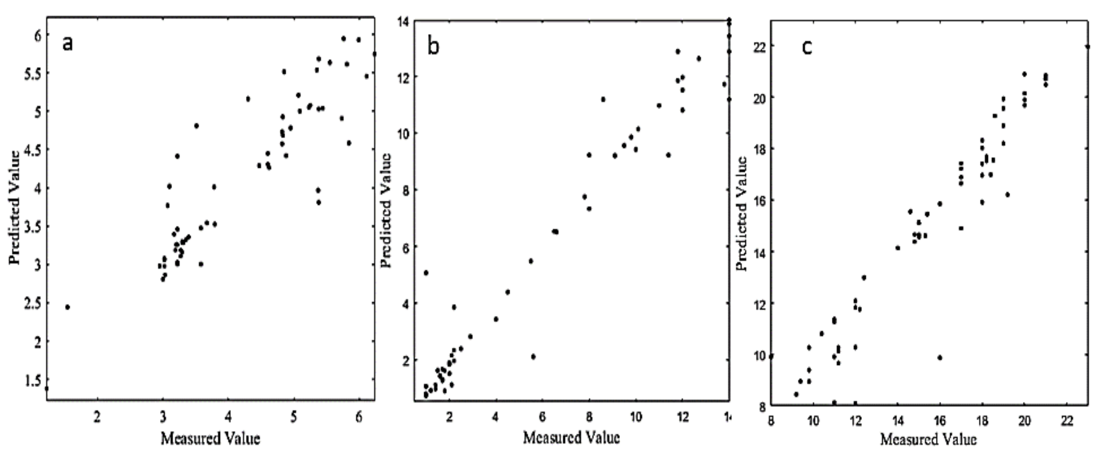
جدول 1- فاکتورهای ارزیابی مدل شبکه عصبی مربوط به متغیرهای خروج

خروجی شبکه	فاکتورهای ارزیابی	فاز آموزش	فاز اعتبار سنجی	فاز آزمون	کل
اسیدیته	RMSE	0/43	0/71	1/19	0/58
	MAPE	7/10	15/04	24/68	9/53
	EF	0/87	0/37	-0/43	0/74
سفتی	RMSE	0/73	2/22	2/67	1/26
	MAPE	9/69	47/09	109/29	22/74
	EF	0/98	0/82	0/28	0/93
قند	RMSE	0/70	1/67	3/43	1/34
	MAPE	4/25	7/73	20/65	6/14
	EF	0/97	0/72	0/07	0/88

جدول 2- مدل‌های رگرسیونی پیش‌بینی کننده حاصل از شبکه عصبی **MLP** برای سه متغیر اسیدیته، سفتی و قند.

فاکتورهای پیش‌بینی	فاز آموزش	فاز اعتبارسنجی	فاز آزمون
اسیدیته	PV=0.81*dv+0.68	PV=0.99*dv+0.52	PV=0.94*dv-0.36
	R^2=0.88	R^2=74	R^2=0.45
سفتی	PV=0.98*dv-0.04	PV=1.17*dv-2.39	PV=1.43*dv+0.07
	R^2=0.98	R^2=0.93	R^2=0.85
قند	PV=1*dv-0.24	PV=0.93*dv-0.08	PV=1.53*dv-10.61
	R^2=0.97	R^2=0.89	R^2=0.88

در شکل 7 نمودارهای مربوط به مقادیر پیش‌بینی شده در مقابل مقادیر واقعی نمایش داده شده است. میزان انحراف از خط وسط نشان‌دهنده اختلاف بین مقادیر پیش‌بینی شده با مقادیر واقعی است. شکل 7 (a)، مقادیر پیش‌بینی شده برای متغیر اسیدیته را نمایش می‌دهد که بیانگر اختلاف بالای بین مقادیر واقعی و مقادیر پیش‌بینی شده است. در شکل‌های 7 (b) و 7 (c) که به‌ترتیب مربوط به پیش‌بینی متغیرهای سفتی و قند هستند، اختلاف بین مقادیر پیش‌بینی شده و مقادیر واقعی به مراتب کمتر از حالت مربوط به متغیر اسیدیته است. به همین دلیل مقدار دقت به‌دست آمده برای فاکتورهای سفتی و قند بیشتر است. با توجه به ضرایب تبیین بالای معادلات برازش نشان داده شده در شکل 7 می‌توان نتیجه گرفت که مدل شبکه عصبی به خوبی توانسته‌اند مقادیر سفتی و قند انبه را برآورد نمایند.



شکل 7- نمایش مقادیر پیش‌بینی شده در مقابل مقادیر واقعی برای سه متغیر اسیدیته (a)، سفتی (b) و قند (c).

در پژوهش مینایی و همکاران (2015) تخمین میزان قند موجود در ریشه‌های چغندرقند با استفاده ازطیف‌سنجی فروسرخ نزدیک مورد مطالعه قرار گرفته است. از روش حداقل مربعات جزئی به‌منظور تخمین استفاده شد که میانگین مربعات خطا برای تخمین عیار برابر با 0/95 و برای مواد جامد محلول برابر با 1/7 به‌دست آمد. پژوهش Kondo و همکاران (2000) نشان داد که استفاده از ماشین بینایی و شبکه عصبی روشی مناسب برای تعیین اسیدیته و محتوای قند پرتقال است. متغیرهای مستقل شامل رنک و ابعاد است. نتایج این پژوهش نشان می‌دهد مقدار ضریب تبیین برای تخمین قند پرتقال برابر با 84 درصد و برای تخمین pH برابر با 83 درصد به‌دست آمده است. در پژوهش شمیلی و همکاران (1386)، نتایج نشان داد که بین مواد جامد محلول و سفتی میوه انبه با ویژگی‌های رنگی تصویر شامل *L و *a همبستگی وجود دارد. در بررسی دیگری، قابلیت استفاده از تصاویر دیجیتال و نرم‌افزار فتوشاپ برای اندازه‌گیری تغییرپذیری رنگ میوه خرمای مضافتی در طول دوره رسیدگی ارزیابی شده است (Afshari-Jouybari and Farahnaky, 2011).

جدول 3- نتایج تحلیل حساسیت حاصل از حذف متغیرهای تأثیرگذار در مدل

وابسته	مستقل	RMSE	MAPE	R^2
اسیدیته	همه متغیرها	0/58	9/52	0/75
	همه متغیرها به‌جز زمان	4/14	97/57	0/02
	همه متغیرها به‌جز L	8/55	190/48	0/01
	همه متغیرها به‌جز a	2/77	66/97	0
	همه متغیرها به‌جز b	4/45	111/24	0/15
	همه متغیرها به‌جز انحراف معیار L	8/61	204/69	0/17
	همه متغیرها به‌جز انحراف معیار a	7/44	167/71	0/05
	همه متغیرها به‌جز انحراف معیار b	6/18	153	0
سفتی	همه متغیرها	1/26	22/74	0/93
	همه متغیرها به‌جز زمان	11/38	424/11	0
	همه متغیرها به‌جز L	19/29	856/89	0/04
	همه متغیرها به‌جز a	7/9	296/12	0/14
	همه متغیرها به‌جز b	13/79	475/72	0/27
	همه متغیرها به‌جز انحراف معیار L	13/20	867/23	0/03
	همه متغیرها به‌جز انحراف معیار a	18/6	772/4	0
	همه متغیرها به‌جز انحراف معیار b	30/7	1279	0/03
قند	همه متغیرها	1/33	14/6	0/91
	همه متغیرها به‌جز زمان	20/58	113/73	0
	همه متغیرها به‌جز L	17/11	66/24	0/06
	همه متغیرها به‌جز a	8/48	39/41	0/01
	همه متغیرها به‌جز b	10/88	62/31	0/09
	همه متغیرها به‌جز انحراف معیار L	16/50	100/34	0/11
	همه متغیرها به‌جز انحراف معیار a	13/21	81/46	0/10
	همه متغیرها به‌جز انحراف معیار b	17/13	103/55	0/04

لازم به ذکر است که در مقابل این روش استفاده از روش رنگ‌سنجی برای پیش‌بینی ترکیب‌های محصولات کشاورزی تحقیقات چندی روی میوه‌های مختلف مانند هلو (Ying *et al.* 2005)، زرد آلو (Carlini *et al.* 2000)، سیب (Lu *et al.*, 2000; Fan *et al.*, 2009)، آووکادو (Clark *et al.*, 2003)، موز (Tarkosova *et al.*, 2000)، پرتقال (Shao *et al.*, 2009) و گوجه‌فرنگی (Shao *et al.*, 2007) صورت گرفته است و نتایج امیدوارکننده‌ای در این مورد گزارش نشده است.

در این پژوهش از تحلیل حساسیت به‌منظور تعیین اثر هر یک از متغیرها به‌صورت جداگانه در مدل پیش‌بینی استفاده شده است. در جدول 3 نتایج حاصل از تحلیل حساسیت بر روی مدل‌های شبکه عصبی برای سه متغیر اسیدیته، سفتی و قند گزارش شده است. به‌طورکلی نتایج حاصل از تحلیل حساسیت نشان می‌دهد در هر سه مدل حاصل‌شده حذف هر یک از متغیرهای مستقل سبب ایجاد خطای بزرگی در مدل شبکه عصبی می‌شود. بنابراین پیش‌بینی ویژگی‌های کیفی میوه انبه می‌تواند تحت تأثیر عوامل مختلفی باشد. نمی‌توان بیان کرد که تنها یک یا چند فاکتور خاص قابلیت این پیش‌بینی را دارند. علاوه بر عوامل ذکرشده در این پژوهش ممکن است عوامل دیگری مانند ابعاد میوه، وزن میوه، زمان برداشت و شرایط محیطی اشاره کرد.

نتیجه‌گیری

در این پژوهش عملکرد شبکه عصبی مصنوعی mlp در پیش‌بینی اسیدیته، سفتی و قند میوه انبه رقم کلک سرخ بررسی شد. از نتایج به‌دست‌آمده این‌طور نتیجه‌گیری می‌شود که مقادیر پیش‌بینی‌شده اسیدیته، سفتی و قند انبه توسط شبکه عصبی از نظر آماری اختلاف معنی‌داری با مقادیر واقعی آن‌ها نداشتند؛ به‌طوری‌که در پیش‌بینی اسیدیته میوه انبه با استفاده از ویژگی‌های رنگی دارای میانگین مربعات خطا نسبت به دو فاکتور سفتی و قند بیشتر است؛ به همین دلیل مقدار دقت به‌دست‌آمده برای فاکتورهای سفتی و قند بیشتر است؛ بنابراین پیش‌بینی سن دو فاکتور با استفاده از شبکه عصبی mlp قابل انجام است. هیستوگرام خطا مربوط به سه مدل شبکه عصبی نشان داد وضعیت شبکه عصبی در دو حالت پیش‌بینی سفتی و قند انبه بهتر از حالت پیش‌بینی اسیدیته است. مقدار MAPE که بیانگر خطای پیش‌بینی شبکه عصبی به‌ترتیب برای سفتی، اسیدیته و قند برابر با 9/53، 22/74 و 6/14 به‌دست آمده است. مقایسه نتایج شبکه عصبی در مراحل آموزش و آزمون نشان داد که این تکنیک می‌تواند به‌عنوان یک روش مطمئن برای تخمین فاکتورهای سفتی و قند از دقت کافی مورد استفاده قرارگیرد و پیش‌بینی اسیدیته با استفاده از این روش با دقت غیرکاربردی امکان‌پذیر است. مقایسه معیارهای عملکردی مدل شبکه عصبی نشان داد که مدل‌های سفتی و قند بسیار نزدیک به یکدیگر هستند؛ درصورتی‌که مدل شبکه عصبی برای اسیدیته بیانگر اختلاف بالای بین مقادیر واقعی و مقادیر پیش‌بینی شده است.

تشکر و قدردانی

در پایان لازم می‌دانیم از گروه مهندسی بیوسیستم دانشگاه فردوسی مشهد و گروه علوم باغبانی دانشگاه هرمزگان کمال قدردانی و تشکر را به خاطر فراهم آوردن تجهیزات و امکانات موردنیاز به عمل آوریم.

منابع

آذرکیش، پ. و شمیلی، م. 1394. تأثیر پوترسین و آب سرد بر ویژگی‌های کیفی و انبارمانی میوه انبه (*Mangifera indica* L). فصلنامه علوم و صنایع غذایی، 47(12)، 74-65.

پوردربانی، ر. قاسم زاده، ح. آقا گل‌زاده، ع. و بهفر، ح. 1388. امکان سنجی درجه‌بندی کیفی سیب با استفاده از پردازش تصویر، مجله پژوهش‌های صنایع غذایی، 19 (1)، 85- 75.

خدابخشیان کارگر، ر. 1394. روش‌های کیفیت‌سنجی غیرمخرب محصولات کشاورزی از اصول تا اجرا، آموزش و ترویج کشاورزی، 272.

خدابخشیان کارگر، ر. عمادی، ب. خجسته‌پور، م. گلزاریان، م.ر. و سازگارنیا، الف. 1394. کیفیت‌سنجی سریع دانه انار با استفاده از طیف‌سنجی مرئی/ مادون قرمز نزدیک، فناوری‌های نوین غذایی، 2(4)، 114-103.

دوستی‌ایرانی، الف. گلزاریان، م.ر. آق‌خانی، م.ح. و صدرنیا، ح. 1394. بررسی تغییرات رنگی و دمایی بافت لهیده شده سیب در طول زمان با استفاده ازپردازش تصاویر مرئی و نقشه‌های گرمایی. پژوهش‌های علوم و صنایع غذایی ایران، 11(5)، 693-677.

سلمانی‌زاده، ف. نصیری، س.م. راحمی، م. و جعفری، ع.ع. 1392. امکان‌سنجی استفاده از جذب اشعه ایکس به عنوان یک روش غیرمخرب برای تعیین برخی از شاخص‌های کیفی میوه انار، علوم باغبانی (علوم و صنایع کشاورزی)، 27(3)، 341-335.

شمیلی، م. گلزاریان، م.ر. آذرکیش، پ. و دوستی‌ایرانی، الف. 1396. استفاده از پردازش تصویر در برآورد خسارت وارده از سرما بر میوه انبه، نخستین کنفرانس بین المللی و دهمین کنگره ملی علوم باغبانی ایران، دانشگاه تربیت مدرس، 13-16 شهریورماه 1396.

عباسی، م. حیدری، م. و دانشور، م.ح. 1391. ارزیابی اولیه خصوصیات میوه درختان گزینش شده انبه (*Mangifera indica* L.) در میناب، تولیدات گیاهی، 35(4)، 129-117.

کلانتری،س. میرزاعلیان دستجردی، ع.م. بابالار، م. زمانی، ذ.الف. 1392. اثر تیمارهای پس از برداشت بر عمر قفسه‌ای و انباری میوه انبه برداشت شده در مراحل مختلف رسیدن، علوم باغبانی ایران، 44(1)، 59-43.

گلزاریان، م.ر. شمیلی، م. دوستی‌ایرانی، الف. و آذرکیش، پ. 1395، تشخیص آسیب‌های سطحی ناشی از صدمات مکانیکی میوه انبه رقم کلک سرخ با استفاده از تکنیک پردازش تصاویر رنگی، پژوهش‌های علوم و صنایع غذایی ایران، 12(5)، 662-652.

گلزاریان، م.ر. صادقی، ف. قانعی، ن. و کاظمی، ف. 1392، ارائه روشی کمی و کیفی در ارزیابی عملکرد فاکتورهای رنگی برای جداسازی گیاهان از پس‌زمینه به‌منظور خودکار کردن شناسایی تصویری گیاهان، هشتمین کنگره ملی مهندسی ماشین‌های کشاورزی (بیوسیستم) و مکانیزاسیون، 9 الی 11 بهمن 1392. دانشگاه فردوسی مشهد.

محمدپور، الف. و سماوی، س. 1393، نکات فنی در برداشت، بسته‌بندی و نگهداری میوه انبه، مؤسسه تحقیقات فنی و مهندسی کشاورزی. 26-1.

میرحسینی، ع. صادقی، ح. و مرادی، ح. 1397، پیشبینی برخی ویژگیهای کیفی میوهٔ انار با استفاده از روش غیرمخرب پردازش تصویر، علوم باغبانی ایران، 49(2)، 451-443.

نیکبخت، ع.م. توکلی‌هشجین، ت. ملکفر، ر. و قبادیان، ب. 1389، کاربرد طیف‌سنجی رامان در بررسی غیرمخرب پارامترهای کیفی گوجه فرنگی، علوم و صنایع غذایی، 7(4)، 33-25.

Afshari-Jouybari, H. & Farahnaky, A. 2011, Evaluation of Photoshop software potential for food colourimetry, *Journal of Food Engineering*, 106, 170-175.

Arzani K. & Koushesh M. 2005, Enhancement of Sultana grape (*Vitis vinifera* L.) maturity by preveraison ethanol and methanol spray, Indian Journal of Agricultural Science, 75(10), 670-672.

Carlini, P. Massantini, R. & Mencarelli, F. 2000, Vis-NIR measurement of soluble solids in cherry and Apricot by PLS regression and wavelength selection, *Journal of Agricultural and Food Chemistry*, 48, 236-242.

Clark, C.J. McGlone, V.A. Requejo, C. White, A. & Woolf, A.B. 2003, Dry matter determination in ‘Hass’ avocado by NIR spectroscopy, *Postharvest Biology and Technology*, 29, 300-307.

Doosti-Irani, O. Golzarian, M.R. Aghkhani, M.H. Sadrnia, H. & Doosti-Irani, M. 2016, Development of multiple regression model to estimate the apple’s bruise depth using thermal maps, *Postharvest Biology and Technology*, 116, 75-79.

Fan, G. Zha, J. Du, R. & Gao, L. 2009, Determination of soluble solids and firmness of apples by Vis/NIR transmittance, *Journal of Food Engineering*, 93, 416-420.

Génard, M. Bertin, N. Borel, C. Bussières, P. Gautier, H. Habib, R. Lechaudel, M. Lecomte, A. Lescourret, F. Lobit, P. & Quilot, B. 2008. Towards a virtual fruit focusing on quality: modelling features and potential uses. *Journal of Experimental* Botany, 58(5): 917-928.

Hertog, M. Nicholson, S.E. & Jeffery, P.B. 2004, the effect of modified atmospheres on the rate of firmness change of ‘Hayward’kiwifruit, *Journal of the Postharvest Biology and Technology*, 31: 251-261.

Jacobi, K. MacRae, E. & Hetherington, S. 2001, Postharvest heat disinfestations treatments of mango fruit (Review). *Scientia Horticulturae*. 89: 171-193.

Kondo, N. Ahmad, U. Monta, M. & Murase, H. 2000, Machine vision based quality evaluation of Iyokan orange fruit using neural networks, *Computers and Electronics in Agriculture*, 29, 135-147.

Léchaudel, M. & Joas, J. 2007. An overview of preharvest factors influencing mango fruit growth, quality and postharvest behaviour. Brazilian Journal of Plant Physiology, 19(4): 287-298.

León, K. Mery, D. Pedreschi F. & León, J. 2006, Color measurement in L*a*b* units from RGB digital images, *Food Research International*, 39, 1084-1091.

Lu, R. Guyer, D. & Beaudry, R.M. 2000, Determination of firmness and sugar content of apple using NIR diffuse reflectance, *Journal of Texture Studies*, 31, 615-630.

Mata, C. Duarte, M.E.M. Borges, F.F. & Barbacena, I.L. 2012, An adaptive threshold level for segmentation of grayscale images using image processing to sort mangoes by weight estimation, *Postharvest Technology in the Global Market*, 934, 943-948.

Medlicott, A.P. Bhogal, M.O. & Reynolds, S.B. 1986. Changes in peel pigmentation during ripening of mango fruit (Mangifera indica var. Tommy Atkins). *Annals of Applied Biology*, 109(3): 651-656.

Minaei, S. Bagherpour, H. Abdollahian Noghabi, M. Khorasani Fardvani, M.E. & Foroughimanesh, F. 2016. A Comparative Study Concerning Linear and Nonlinear Models to Determine Sugar Content in Sugar Beet by Near Infrared Spectroscopy (NIR). *Journal of Food Biosciences and Technology*, 6(1): 13-22.

More, T.A. Kambale, A.B. Karale, A.R. Garad, B.V. & Shirsath. H.K. 2004, Selection of seedling mango types for pickling characters, *Journal of Maharashtra Agricultural Universities*, 29, 348-349.

Nordey, T. Léchaudel, M. Génard, M. & Joas, J. 2014, Spatial and temporal variations in mango colour, acidity, and sweetness in relation to temperature and ethylene gradients within the fruit. *Journal of plant physiology*, 171(17): 1555-1563.

Pedreschi, F. Leon, J. Mery, D. & Moyano, P. 2006. Development of a computer vision system to measure the color of potato chips. *Food Research International*, 39(10): 1092-1098.

Rathore, H.A. Masud, T. Sammi, S. & Soomro, A.H. 2007, Effect of Storage on Physico-Chemical Composition and Sensory Properties of Mango Variety Dashehari, *Pakistan Journal of Nutrition*, 6(2), 143-148.

Rohani, A. Abbaspour-Fard, M.H. & Abdolahpour, S. 2011. Prediction of tractor repair and maintenance costs using Artificial Neural Network. *Expert Systems with Applications*, 38(7): 8999-9007.

Roussos, P.A. Sefferou, V.Denaxa, N.K. Tsantili, E. & Stathis, V. 2011, Apricot (*Prunus arm eniaca* L.) fruit quality attributes and phytochemicals under different crop load, Scientia Horticulturae, 129, 472-478.

Shao, Y.H. He, Y. Bao, Y.D. & Mao, J.Y. 2009, Near-infrared spectroscopy for classification of oranges and prediction of the sugar content, *International Journal of Food Properties*, 12, 644-658

Shao, Y.H. He, Y. Gomez, A.H. Pereir, A.G. Qiu, Z. & Zhag, Y. 2007. Visible/near infrared spectrometric technique for nondestructive assessment of tomato 'Heatwave' (*Lycopersicum esculentum*) quality characteristics, *Journal of Food Engineering*, 81, 672-678.

Tarkosova, J. & Copikova, J. 2000, Determination of carbohydrate content in bananas during ripening and storage by near infrared spectroscopy. *Journal of Near Infrared Spectroscopy*, 8, 21–26.

Ying, Y.B. Liu, Y.D. Wang, J.P. Fu, X.P. & Li, Y.B. 2005, Fourier transforms near-infrared determination of total soluble solids and available acid in intact peaches, American Society of Agricultural Engineers, 48, 229-234.

Iranian Food Science and Technology Research Journal
Vol. 16, No. 1, Apr. May. 2020, p. 145- 156

نشریه پژوهشهای علوم و صنایع غذایی ایران
جلد 16، شماره 1، فروردین - اردیبهشت 1399 ص. 156-145

Predicting quality characteristics of Mango of Kelk-e Sorkh variety using color image processing and artificial neural networks

O. Doosti Irani[1], A. Rohani[2], M. R. Golzarian[3], M. Shamili[4], P. Azarkish[5]

Received: 2018.12.17
Accepted: 2019.09.22

Introduction: The diversity and abundance in quality properties of agricultural products are leading factors to develop non-destructive methods. Machine vision and artificial intelligence are powerful techniques in detection of many physical, mechanical and chemical properties of agricultural products. Prior to exporting, fruits are sorted in terms of their shapes, volumes or weights. Non-destructively taste-based sorting can be of importance in terms of markability and application. Artificial Neural Network (ANN) has been introduced as a new method to predict quality parameters such as firmness, total sugar content (TSC) and pH of agricultural products and to grade the products accordingly.

Material and Methods: In this research, the quality properties of Mango (Kelke- Sorkh var) were predicted using the combination of image processing and artificial intellect techniques. The mango samples were harvested from the orchard in Minab, Hormozgan province in Iran. The samples were transferred to computer vision lab, room temperature of 24°C and 22% RH. The samples were divided into three groups for temperature treatment. They were kept at three temperature levels of 5°C, 15°C and 24°C (control group) for 48 hours. The sample were then placed in room temperature and were imaged every second day for 14 day period. After imaging, each sample was undergon destructive tests for determining their quality attributes including sugar content, firmness and pH. The images were taken by a digital camera in visible spectrum (Nickon Coolpix p510, Nikon Inc, Japan). The taken images were, then, transferred to Matlab software environment (Mathworks Inc, US) for analysis and processing. The color factors from regions of intrest were extracted from the images in L*a*b* color space. The segmentation of images was performed by thresholding (threshhold value of 0.3) the image of difference between red and blue channels of taken RGB images. The conversion of RGB color space to L*a*b* was done by converting RGB image to XYZ basic color space first and before converting X, Y, and Z basic color components to L*, a*, b* color factors. The L* represent the lightness in the image from black (0) to white (100). In this project, a multilayer perceptron neural network with a hidden layer was used. The optimum number of neurons in the hidden layer was found to be 25. The maximum iterations was set as 1000 and the learning rate was set as 0.001.

Results and discussions: The input variables to the network were temperature treatment at three levels (control, 5°C and 15°C), the color factors (L*, a* and b*) and the variations of three color factors across the regions of interest (standard deviations of L*, a* and b*). The output variables were sugar content, pH and texture firmness. The results showed that the accuracy of the ANN model on the prediction of pH, sugar content and firmness were 45%, 85 and 88%, respectively. Although the accuracy of ANN model for predicting pH from color factors was rather low, this model was able to predict firmness and sugar content with highly accurately. The histogram of errors among three ANN models also showed the ANN model for predicting firmness and sugar content performed better than that for predicting pH. The MAPE prediction error were 9.53, 22.74 and 6.14, respectively, for predicting firmness, pH and sugar content. Comparing the results from the network in training and testing stages showed that ANN can be considered as a reliable method for estimating quality factors of firmness and sugar content with high accuracy and estimating pH with rather non-applicable accuracy.

Keywords: Artificial Intelligence, Mechanical Properties, Postharvest Quality assessment.

1, 2 and 3. PhD. Student, Assistant Professor and Associate Professor, Agricultural Machinery, Faculty of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran
4. Assistant Professor, Department of Horticultural Science and Landscape Engineering, Hormozgan University, Iran.
5. PhD. student, Department of Horticultural Science and Landscape Engineering, Ferdowsi University of Mashhad
(* Corresponding author email address: m.golzarian@um.ac.ir)